

WEEKLY REPORT

张建伟

March 10, 2019

1 上周工作

1.1 肝肿瘤分割

目前的主干网络为 2D UNet, 本周实验了几种策略进行分割肿瘤:

- **Only tumor:** 单个 UNet 同时分割肝脏和肿瘤 \leftrightarrow 单个 UNet 仅分割肿瘤
- **Triplet:** 网络输入单个 (横断面) 切片进行训练 \leftrightarrow 网络输入相邻的三个切片进行训练
- **Spatial Guide, SG:** 半自动方法 (需要交互), 使用在有肿瘤的位置添加高斯分布引入先验信息, 作为额外的通道输入网络. 推断 (test/inference/predict) 时每个肿瘤仅提供第一个切片的 SG, 下一个切片的 SG 从上一个切片的分割结果中产生.
- **Fake Guide, FG:** 在 SG 的基础上, 增加一些假的肿瘤位置作为输入, 让模型在使用位置先验的同时具有区分真假 SG 的能力.
- **Random Guide, RG:** 在 SG 的基础上, 随机地不给模型提供 SG, 让模型在使用位置先验的同时具有寻找其他可能肿瘤的能力.
- **Atrous:** 在 UNet 中使用膨胀卷积代替普通卷积以减少池化的次数.
- **Classify:** 模型输入 bounding boxes (同时有肿瘤和假阳性肿瘤, 假阳性由先前模型预测的结果提供), 在 UNet 的顶层增加一个分类分支对 bounding boxes 所框出的目标进行二分类, 以提高模型对真假肿瘤的判别能力. 在推断时从 UNet 分割分支输出的结果中获取目标

bounding box 的 proposals 并通过分类分支计算得分以尽可能排除假阳性.

目前的实验结果 (肝脏的分割精度均在 96% 以上, 下面不再列出; 训练集 92 个 CT 序列, 验证集 22 个 CT 序列) 如下表:

Configuration	Dice score of tumor
UNet	—
UNet+Triplet	0.703
UNet+SG+FG	0.570 (0.774)
UNet+Triplet+SG+FG	0.714 (0.782)
UNet+Triplet+SG+FG+RG	0.738 (0.760)
UNet+Triplet+SG+FG+Atrous	0.697 (0.795)
UNet+Classify	—
OnlyTumor+SG+FG+RG	0.668 (0.765)

上表中带 SG 的均为半自动过程, 表中给出了每个肿瘤仅在一个切片中给定位置的结果, 括号中为所有切片均给定位置的结果.

2 下周工作

- 经过对分割结果的检查, 发现由于我们选择了在第一个切片中给定位置, 因此该切片中肿瘤区域极小时可能会被漏掉, 从而导致后续切片中该肿瘤整个被漏掉. 因此要考虑在中间的某一切片提供 SG, 然后分别向两侧进行迭代 (即每个 case 沿两个方向分割两次对结果进行融合).
- 完成 Classify 部分的代码并进行实验
- Atrous 膨胀卷积的策略对于完全先验的情况有提升, 对局部先验没有提升, 猜测可能的原因是当前的模型鲁棒性不好 (即第一点问题), 待上一步改正后再次实验. 同时考虑好的膨胀卷积策略, 因为 LiTS 中的肿瘤非常小, 所以利用膨胀卷积减少下采样次数以避免过多细节信息的损失是有好处的.
- 考虑一种数据集的平衡策略以提高离群样本的精度.

3 论文阅读

3.1 Graph Neural Networks: A Review of Methods and Applications

2019 年 1 月图神经网络的一篇综述, 主要介绍了 GNNs 的提出 (原始 GNNs), 几种图的变体 (有向图, 异质图, 边带信息的图), 传播方式的变体 (卷积, 注意力机制, 跳跃连接). 目前已有的 GNNs 框架有: Message Passing Neural Networks, Non-local Neural Networks, Graph Networks. 最后列举了一些图网络在各领域的应用 (物理, 化学, 生物, 知识图谱, 图像, 文本等).

3.2 Mask Scoring R-CNN

本文被 CVPR 2019 接收. 本文聚焦于实例分割任务, 目前已有的实例分割框架如 Mask R-CNN 存在一个缺陷: 用 Bounding box 的分类置信度作为 mask 的得分, 导致了 mask 的得分与 mask 实际的分割精度不匹配. 因此本文在原有 Mask R-CNN 模型的基础上增加了第四个分支, 根据 roi 的分割 mask 输出和中间层的特征直接预测 mask 的分割精度, 从而迫使 mask 的得分和分割的精度趋于一致. 而这种潜在的约束经过实验证明提升了最终的实例分割的性能.




Figure 1

3.3 An Analysis of Deep Neural Network Models for Practical Applications

本文把目前流行的几种神经网络框架在统一的标准下进行了实验并比较. 从图中可以发现 VGG 模型参数量和计算量都是非常大的; 而 ResNet 系列

(残差连接) 和 Inception 系列 (分组卷积, 分离卷积) 模型参数量适中, 分类精度也较高; GoogLeNet, ENet 和 NIN 的参数量和计算量非常小, 但分类精度也相对更低. 此外, 本文也考察了这些模型的推断时间, 耗电量, 内存随批大小的增长规律等. 在推断时所需要的时间线性依赖于模型所需要的操作数. (评论: 通常来说操作数随模型参数量的增大而增大, 但也有不同的情况, 如 DenseNet, 通过反复迭代以降低参数使用量, 但极大地增加了操作数.)




Figure 2